



Archives de hier et de demain

Laurent Romary

► To cite this version:

Laurent Romary. Archives de hier et de demain. Master. Master 2 Archives, France. 2019. hal-03215531

HAL Id: hal-03215531

<https://inria.hal.science/hal-03215531>

Submitted on 3 May 2021

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Distributed under a Creative Commons Attribution| 4.0 International License

Archives de hier et de demain

Laurent Romary

Inria & DIM MAP Dopamines

Présentation personnelle rapide

- Recherche en informatique : ancrée sur une démarche pluri-disciplinaire
 - Traitement automatique des langues
 - Modélisation de données en sciences humaines (langue, documents)
- Du modèle au standard : participation à la normalisation internationale
 - *Text Encoding Initiative* : consortium de référence pour la représentation numérique de textes
 - Comité TC 37 de l'ISO (*Langue et terminologie*)
- Contribution aux infrastructures européennes
 - Initiateur (depuis 2006) et directeur (2014-2018) de l'infrastructure DARIAH ERIC
- Une implication (obstinée) dans la science ouverte
 - CNRS, Société Max Planck, Inria; membre du SPSO (Secrétariat Permanent pour la Sciences Ouverte)
 - Déploiement de HAL, développement des centres de ressources numériques (bases des consortiums Huma-Num), obligation de dépôt dans HAL à Inria

Archives et recherches en numérique

- Gérer le tournant numérique
 - Accélération du processus de numérisation de documents anciens, couplé à une production de données naturellement numériques (*born-digital*)
 - Présentation de quelques projets couplant recherche et infrastructure à différentes étapes de ces développements
- Présentations de différents projets liés au lien entre archives et numérique
 - Partie 1: travail sur les matériaux anciens (ou moins anciens)
 - Intégration de données hétérogènes en EAD dans le projet EHRI
 - Extraction d'information à partir d'actes notariés (Archives Nationales)
 - Numérisation et structure: donner du sens
 - Grobid et entity-fishing
 - Partie 2: archives des données de la recherche
 - Travailler à la traçabilité des données
 - Scénario E-RIHS Enquête Iperion CH
 - Pistes à suivre: Standard (cf. Vienne) – TEI – SSK; Charte – DMP; Sciences Call – questionnaire

Un peu de contexte: TEI et EAD

- TEI – Text Encoding Initiative
 - Directives pour le codage de données textuelles en XML
 - Initié en 1987 – édition courante P5
 - Standard ouvert (GitHub), maintenance réactive (2 releases par an)
 - ODD (One Document Does it all): langage de spécification de la TEI
- EAD - Encoded Archival Description
 - Encodage des instruments de recherche archivistiques en XML (importance du niveau collection vs. objet)
 - Initié en 1993, EAD 1.0 (1998) ... EAD3 (2015)
 - Maintenance par la *Society of American Archivists* et la Bibliothèque du Congrès
 - Inspiré de la TEI (cf. D. Pitti)
 - Permet un alignement sur la norme ISAD(G)

Remerciements à Veerle Vanden Daelen, Charles Riondet et toute l'équipe du projet EHRI

INTÉGRATION DE DONNÉES HÉTÉROGÈNES ISSUES DES ARCHIVES DE L'HOLOCAUSTE

EHRI: Basic information

- EHRI's second phase (2015-2019) as an EU financed project with a total budget of almost 8 mio €
- 24 partner institutions from 17 countries: Research institutions, archives and e-science specialists
- EHRI's goal: Support research into the Holocaust and help networking of Holocaust researchers and archives



EHRI: Partner institutions


- NIOD, Institute for War, Holocaust and Genocide Studies (Amsterdam): Overall project coordination
- Yad Vashem (Jerusalem)
- CEGESOMA (Brussels)
- King's College (London)
- Institute for Contemporary History (Munich)
- Jewish Museum in Prague
- DANS (Den Haag)
- Wiener Library (London)
- Vienna Wiesenthal Institute for Holocaust Studies
- ŻIH (Warsaw)
- Mémorial de la Shoah (Paris)
- International Tracing Service (Arolsen)
- USHMM (Washington D.C.)
- Bundesarchiv (Berlin / Koblenz)
- Elie Wiesel National Institute for the Study of the Holocaust in Romania (Bucharest)
- Hungarian Jewish Archives (Budapest)
- Vilna Gaon State Jewish Museum
- Dokumentačné stredisko holokaustu (Bratislava)
- Foundation Jewish Contemporary Documentation Center CDEC (Milan)
- The Jewish Museum of Greece (GR)
- Ontotext (Sofia)
- INRIA (Le Chesnay)
- Stowarzyszenie Centrum Badań nad Zagładą Żydów (Warsaw)
- Kazerne Dossin: Memorial, Museum and Documentation Centre on Holocaust and Human Rights (Mechelen)

EHRI Aims

The main objective of EHRI is to support the Holocaust research community by

1. **integrating** information on key archival **collections** and **institutions** into an online portal
2. **encouraging** collaborative Holocaust **research** and investigating new methodologies

www.ehri-project.eu




Why EHRI?

- **Fragmentation and dispersal of archival sources**
 - Geographical scope Holocaust
 - Attempts to destroy the evidence
 - Migration of Holocaust survivors
 - Multiple documentation projects after the war
- **Internationalization Holocaust research**
 - Holocaust in Eastern Europe
 - New levels of collaborative research
- **New opportunities for digital research**



Seminars, Online Courses, Document Blog

- **Methodological Seminars**, including an upcoming seminar for **conservationists** working on Holocaust material
- Next to the existing **Online Course** <http://training.ehri-project.eu> , e.g. **interactive courses** and Bundesarchiv-written course on **German Archivistics (Aktenkunde)**
- **Workshops** on specific topics, **Research Guides** (e.g. on **Theresienstadt**, <https://portal.ehri-project.eu/guides/terezin>) and upcoming **online editions** as resources
- The **EHRI Document Blog** (<https://blog.ehri-project.eu/>)



EHRI online courses -

<https://training.ehri-project.eu>

EHRI ONLINE COURSE IN HOLOCAUST STUDIES

[overview](#) [contact](#)



Welcome to the EHRI Online Course in Holocaust Studies. With this growing resource, we want to provide teachers, lecturers and students with source material and background information in order to give them an overview on recent trends in historiography. Since it is not possible to cover all the manifold topics encompassed by modern historical Holocaust research, EHRI has decided to develop a course that teaches by using selected representative examples: five overarching topics have been developed for the online course. Each of these topics is used to focus on a critical analysis of sources within the context of the current state and methods of Holocaust research. ...❖

1

Ghettos under Nazi Rule

The majority of Jews persecuted by the Nazis shared the experience of being forced to live in a ghetto for a certain period of time. Some of these ghettos existed for several years, others only for a few weeks or even days. While several ghettos were hermetically sealed and surrounded by a wall or a fence, others remained open and were only defined by designating certain streets.



2

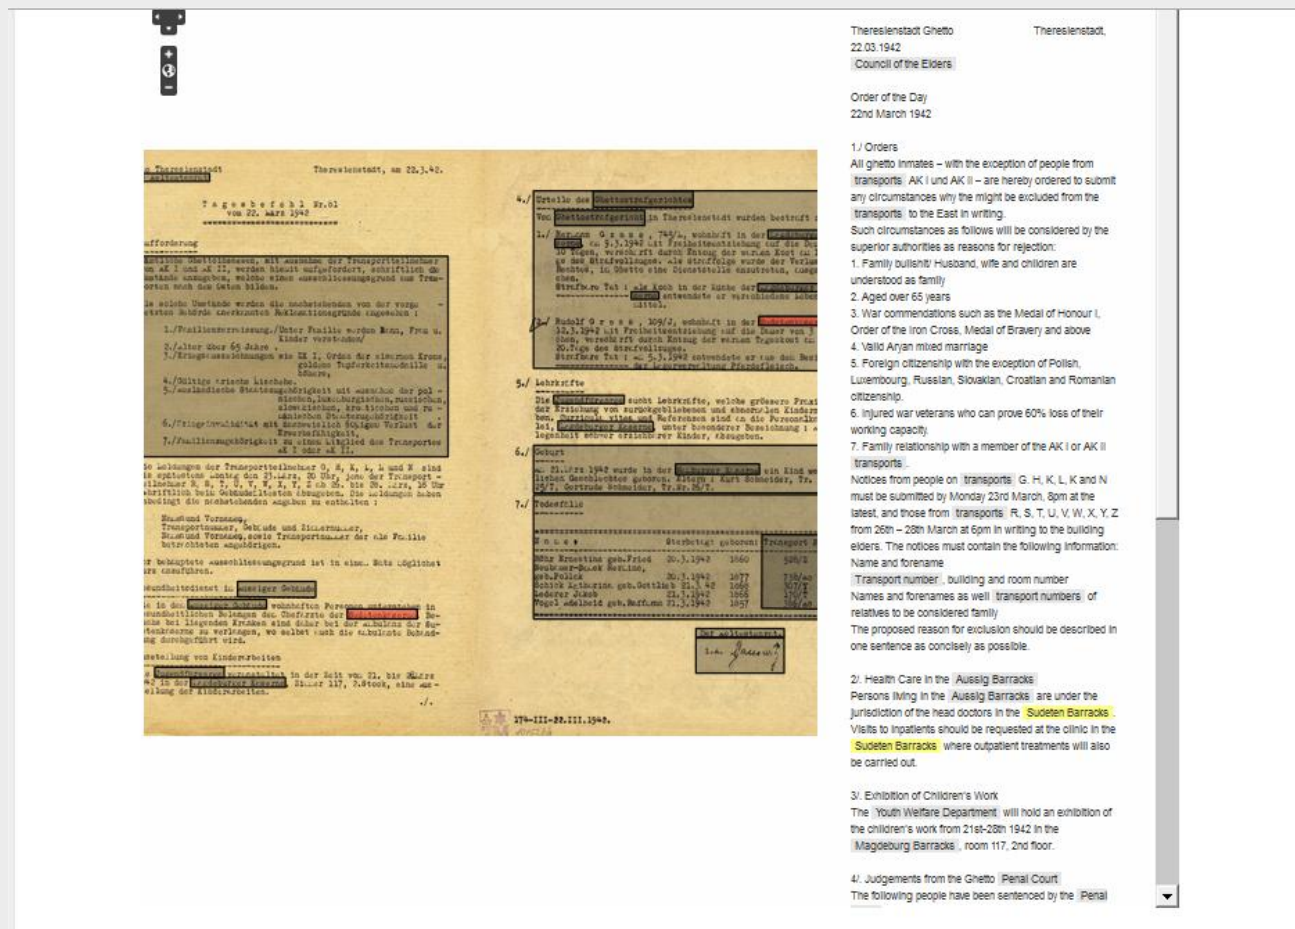
The Nazi Camps and the Persecution and Murder of the Jews

The camps, more than any other phenomenon created by the Nazi regime, became the utmost symbol of the inapplicable cruelty and the high-handed



unguided online course with 6 units; tutored online course with 17 chapters

Innovative platform for the interpretation, visualisation and contextualisation of Holocaust sources



and: EHRI Portal - <https://portal.ehri-project.eu/>



The EHRI portal offers access to information on Holocaust-related archival material held in institutions across Europe and beyond. For more information on the EHRI project visit <http://ehri-project.eu>.

Countries

EHRI national reports provide an overview of the Second World War and Holocaust history as well as of the archival situation in the covered countries.

Archival Institutions

An inventory of archival institutions that hold Holocaust-related material.

Archival Descriptions

Electronic descriptions and finding aids of Holocaust-related archival material.

57 country reports, >1,900 descriptions of institutions, >230,000 archival descriptions

The EHRI Portal

The goal is to expand the **online inventory of institutions and collections** pertaining to the Holocaust in Europe, Israel and beyond

- Making sources visible in a systematic fashion in order to counteract the fragmentation of the sources
- Reveals interconnections (e.g. through a multilingual thesaurus with approx. 5470 terms; collation of authority files; relationships between originals and copies)
- EHRI focuses on **collection descriptions** – it is not aiming to be a “scan depository”, nor does it aim to be a complete public database on the (often privacy sensitive) file or document level (although we will take those descriptions if we can have them)
- The ultimate goal is to connect archives and users (mutually useful -> e.g. expert user feedback)

EHRI Database

Country reports (57 countries)



Entry on the individual archive (over 1,900)

Hrvatski Državni Arhiv

Identity area

EHRI Identifier	2219
Authorized form of name	Hrvatski Državni Arhiv
Parallel form(s) of name	<input type="radio"/> Croatian State Archives
Type	State and Province Archives

Contact area

Contact information	(Primary contact)
Address	Marulićev trg 21 Zagreb Croatia
Telephone	385 1 420 272 / 445 609
Fax	385 1 446 325
Email	hda@arhiv.hr
URL	http://www.arhiv.hr/ Import from EHRI contact spreadsheet
Contact information	Vlatka Lemić
Email	

Upload limit

for Hrvatski Državni Arhiv 0 GB of Unlimited

Holdings

- ☐ Ministarstvo pravosuđa i bogoštovlja Nezavisne Države Hrvatske (draft)
- ☐ Ministarstvo unutarnjih poslova Nezavisne Države Hrvatske (draft)
- ☐ Ministarstvo vanjskih poslova Nezavisne Države Hrvatske (draft)
- ☐ Ministarstvo zdravstva i udruge Nezavisne Države Hrvatske (draft)
- ☐ Odbor u stvari podavanja Židova za potrebe države (draft)
- ☐ Ravnateljstvo ustaškog redarstva. Židovski odsjek (fond) (draft)
- ☐ Savska banovina, odjeljak upravnog odjeljenja za

Individual entries (collections / units) (tens of thousands)

Collection HR-HDA-1514 - Ustaško povjereništvo za grad i kotar Koprivnicu (draft)

Identity area

Reference code	HR-HDA-1514
Title	Ustaško povjereništvo za grad i kotar Koprivnicu
Other form(s) of title	
Date(s)	<input type="radio"/> 1941 - 1942 (Creation)
Level of description	Collection
Extent and medium	1 box

Context area

Name of creator	Ustaško povjereništvo za grad i kotar Koprivnicu
Biographical history	
Repository	Hrvatski Državni Arhiv
Archival history	
Immediate source of acquisition or transfer	

Content and structure area

Scope and content	The collection holds partially saved lists of prisoners, mostly Jews, such as prisoners in Jasenovac (vj. 1941), women and children in Đakovo camp (SD, 26.2. And 06.03.1942.), and Loborgrad (sd), deaths in Đakovo (09.12.1941.) and Loborgrad (1942), list of young people who had been taken to camp Danica (1941), a list of 507 deaths from the camp
-------------------	--

Archival institution

Hrvatski Državni Arhiv

Creator(s)

- ☐ Ustaško povjereništvo za grad i kotar Koprivnicu

Collection

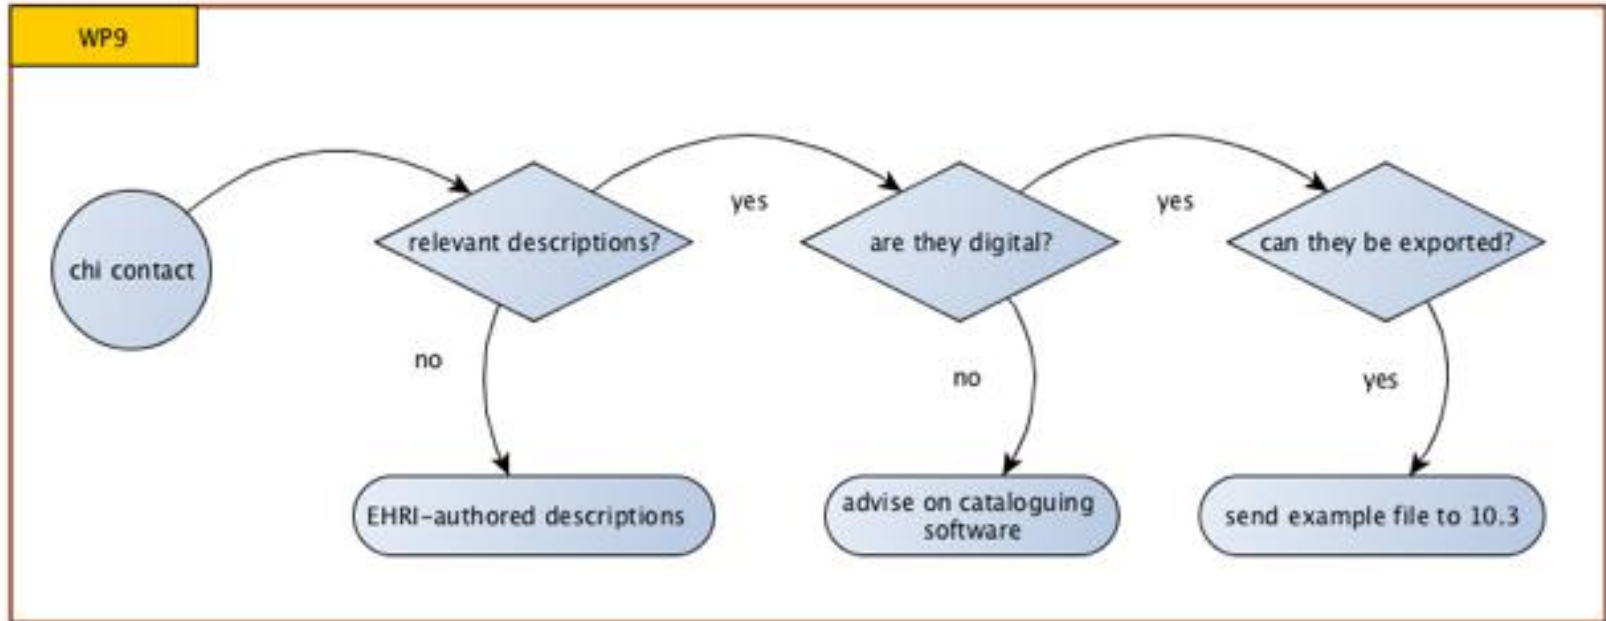
Collection HR-HDA-1514 - Ustaško povjereništvo ...

Export


- ☐ Dublin Core 1.1 XML
- ☐ EAD 2002 XML

[EHRI Portal](#)

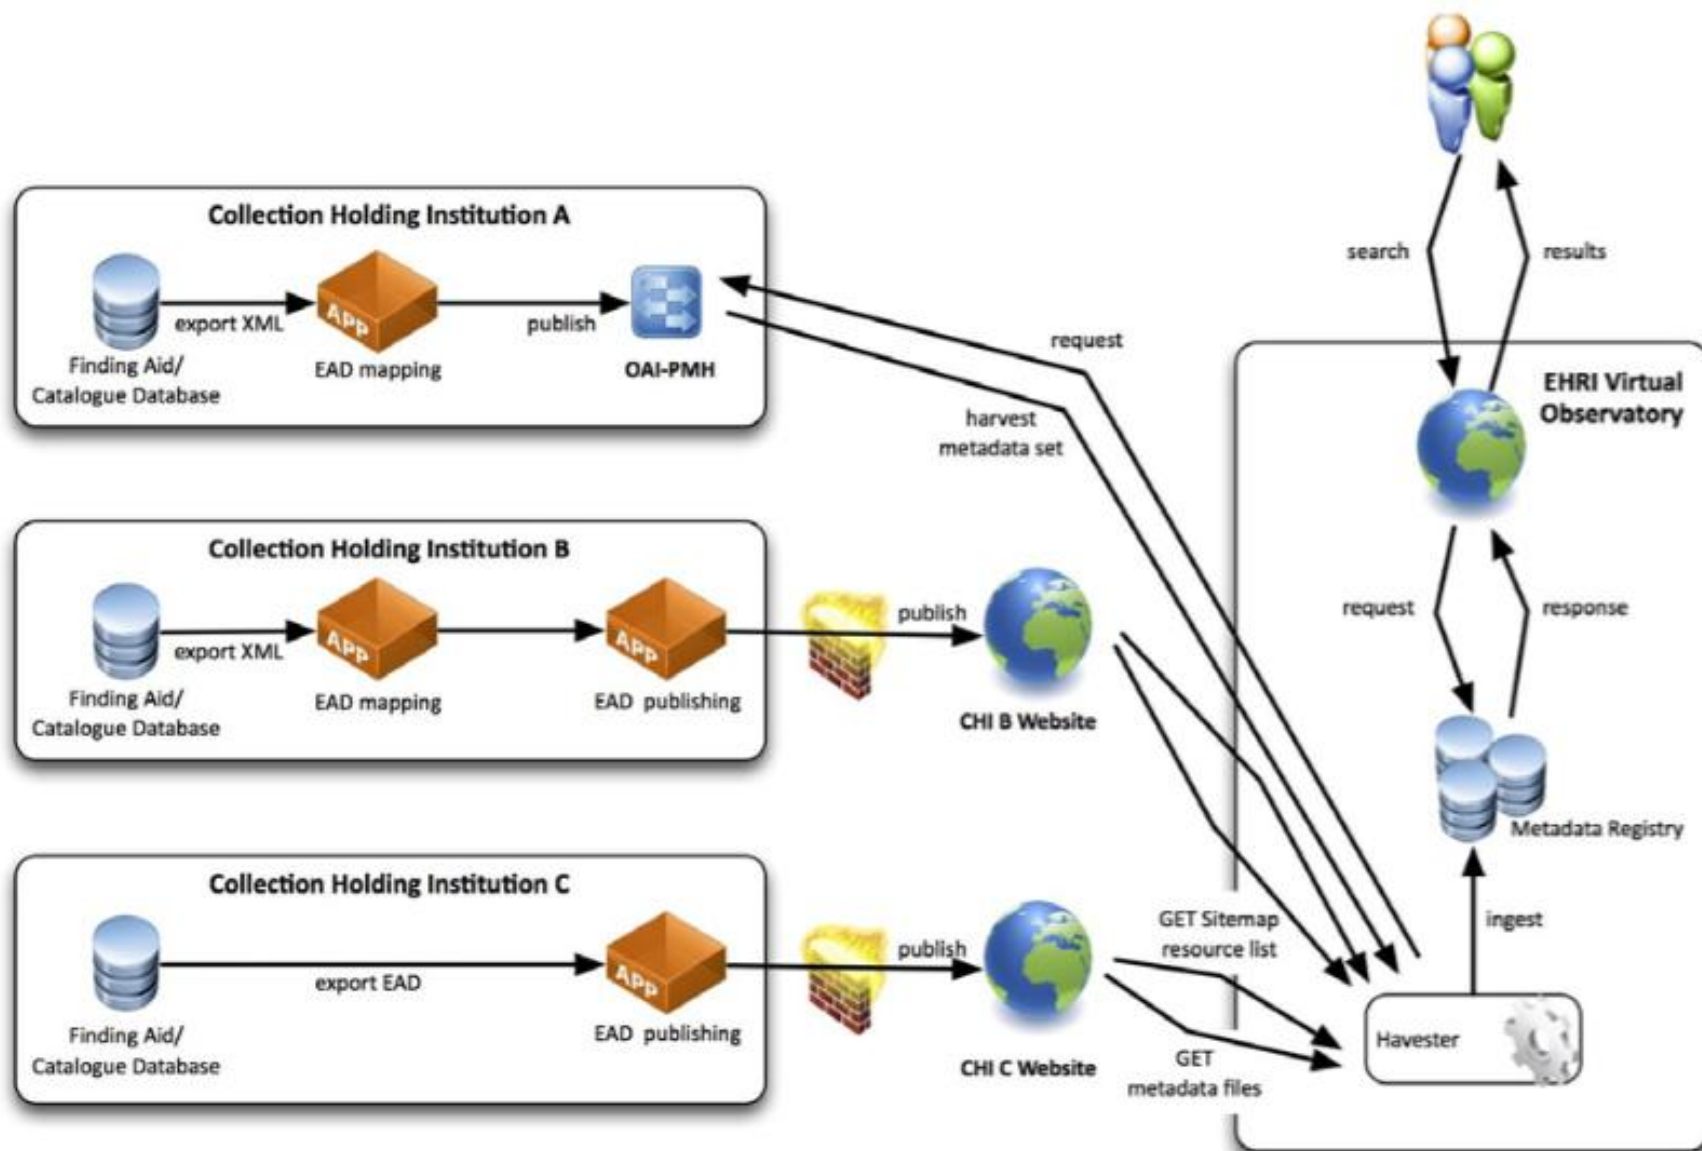
Integration of collection descriptions (I)



Integration of collection descriptions (II)



Data Integration via mapping & publishing tool



Manual repository descriptions

Create Repository

Identifier *

006209

Minimum length: 2

Language of Description

◀ Identity Area

◀ Address Area

◀ Description Area

◀ Access Area

◀ Services Area

◀ Control Area

◀ Administration

[Formatting tips](#)

Identity Area

Authorized Form Of Name

Parallel Names ☐

Other Names ☐

Address Area

Add Address

Description Area

History

Geographical and Cultural
Context

Mandates/Sources of
Authority

Tell people what you're doing (optional, 400 characters max)...

Create Repository

Cancel

Creating collection or child item descriptions

Update Collection

Identifier *

AIMTH.01

Alt. Identifiers +

Language of Description

English

◀ Identity Area

◀ Context Area

◀ Content Area

◀ Conditions Area

◀ Materials Area

◀ Control Area

◀ Administration

Formatting tips

Identity Area

Title

Αρχείο της Ιεράς Μητρόπολης Θεσσαλονίκης

Parallel Names +

Archive of the Holy Diocese of Thessaloniki

Archeio tis Ieras Mitropolis Thessalonikis

Web Source

Description ID (Optional)

Dates +



Year



1874



2014

Level of Description

Collection

Extent and Medium

the extent and medium was not provided.

Tell people what you're doing (optional, 400 characters max)...

Update Collection

Cancel

Manual collection updates

Update Collection

Identifier *

AIMTH.01

Alt. Identifiers +

Language of Description

English

◀ Identity Area

◀ Context Area

◀ Content Area

◀ Conditions Area

◀ Materials Area

◀ Control Area

◀ Administration

Formatting tips

Identity Area

Title

Αρχείο της Ιεράς Μητρόπολης Θεσσαλονίκης

Parallel Names +

Archive of the Holy Diocese of Thessaloniki

Archeio tis Ieras Mitropolis Thessalonikis

Web Source

Description ID (Optional)

Dates +



Year



1874



2014

Level of Description

Collection

Extent and Medium

the extent and medium was not provided.

Tell people what you're doing (optional, 400 characters max)...

Update Collection

Cancel

The EHRI EAD customisation model

Focus on the role and the value of community standards, like EAD and TEI in data integration, enrichment, sharing lifecycle.

- Interoperability
- Enrichment
- Favour new uses

EAD, what's wrong with it?

Since the beginning of EAD, its “permissiveness” is seen as a challenge or a weakness :

Shaw 2001:

"A more prescriptive descriptive standard (...) will greatly enhance the potential for machine processing of finding aids across repositories".

Bunn 2013:

- Need to "Draw a distinction between information exchange and archival description"
- "Still no standard for archival description"

EAD, what's wrong with it?

EAD doesn't have all the means to handle its flexibility.

How to preserve meaning and content?

→ Exchange and connect archival data together, and together with others resources available online

RiC (Records in Context) → New paradigm? Definitive solution?

EHRI and standards

- EAD2002 is the pivot format for automatic ingestion of archival descriptions.
- Ingestion of data in many formats
 - EAD1, Dublin Core, home made formats
 - EAD 2002 with very different encoding guidelines
- EHRI has its own specific description rules

Project-specific EAD customizations

What is customization?

- Narrowing EAD countless encoding possibilities
- Adding quality checks
- Content-oriented rules
- **Not modifying the schema**

TEI long lasting experience // One document does it all (ODD)

Maintain both the technical and editorial content within a single framework.

→ Schema fragments, prose documentation and reference documentation in a single document

ODD allows for total flexibility to model specific subsets or extensions of the described format.


TEI long lasting experience // One document does it all (ODD)

- Straightforward way to customize an XML format according to specific practices and document this customization
- Possible to describe and generate any schema and its documentation with XSL transformations
 - TEI Roma service
 - Saxon or other engine

Defining an XML element with ODD

```
<elementSpec ident="c01" module="EAD">
  <gloss>Component (First Level)</gloss>
  <desc>A wrapper element that designates the top or first-level subordinate
    part of the materials being described. Components may be either
    unnumbered <gi>c</gi> or numbered <gi>c01</gi>, <gi>c02</gi>, etc. The
    numbered components <gi>c01</gi> to <gi>c12</gi> assist a finding aid
    encoder in nesting up to twelve component levels accurately.</desc>
  <classes>
    <memberOf key="att.EADGlobal"/>
    <memberOf key="att.desc.c"/>
  </classes>
  <content>
    <rng:optional>
      <rng:ref name="head"/>
    </rng:optional>
    <rng:ref name="did"/>
    <rng:zeroOrMore>
      <rng:ref name="model.desc.full"/>
    </rng:zeroOrMore>
  </content>
</elementSpec>
```

Generate schema and documentation



Appendix A.1.22 <c01>

<c01> (Component (First Level)) A wrapper element that designates the top or first-level subordinate part of the materials being described. Components may be either unnumbered [<c01>](#) or numbered [<c01>](#), [<c02>](#), etc. The numbered components [<c01>](#) to [<c12>](#) assist a finding aid encoder in nesting up to twelve component levels accurately.

Namespace	http://www.tei-c.org/ns/1.0
Module	EAD
Attributes	att.EADGlobal (@id, @altrender, @audience, @encodinganalog) att.desc.c (@level, @otherlevel)
Contained by	EAD: dsc
May contain	EAD: accessrestrict accruals acqinfo altformavail appraisal arrangement bibliography bioghist c02 controlaccess custodhist dao daogrp descgrp did dsc fileplan head index note odd originalsloc otherfindaid phystech prefercite processinfo relatedmaterial scopecontent separatedmaterial thead userrestrict

```
<define name="c01">
  <element name="c01">
    <a:documentation xmlns:a="http://relaxng.org/ns/compatibility/annotations/1.0">(Component
      (First Level)) A wrapper element that designates the top or first-level subordinate part
      of the materials being described. Components may be either unnumbered c or numbered c01,
      c02, etc. The numbered components c01 to c12 assist a finding aid encoder in nesting up
      to twelve component levels accurately.</a:documentation>
    <optional>
      <ref name="head"/>
    </optional>
    <ref name="did"/>
    <zeroOrMore>
      <ref name="model.desc.full"/>
    </zeroOrMore>
  </element>
</define>
```

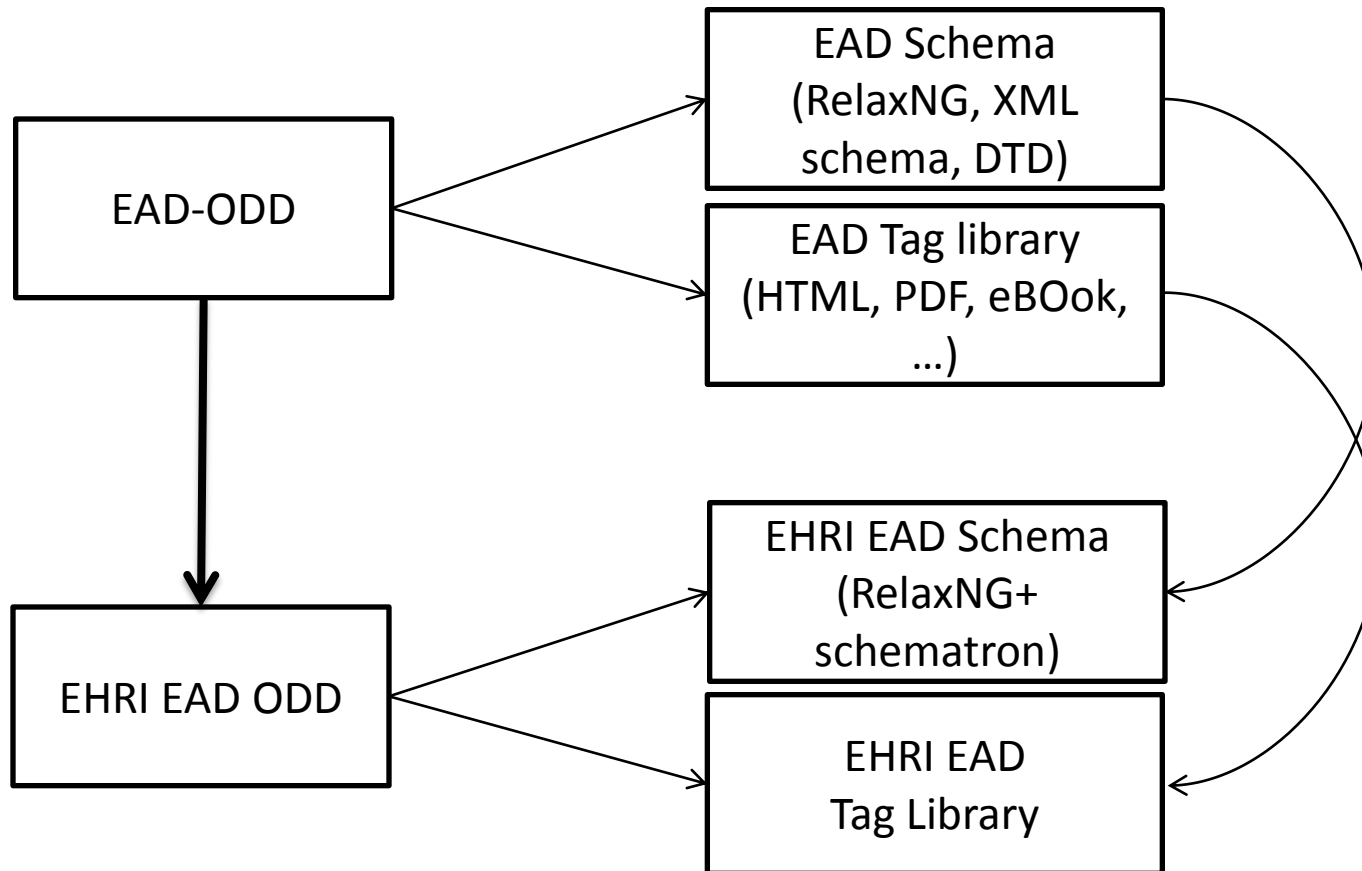
One document does it all and EAD

- We used ODD to cover EAD entirely
 - Official EAD schema (RelaxNG) : www.loc.gov/ead/ead.rng
 - Guidelines provided by the Library of Congress: <http://loc.gov/ead>
- Maintained by Parthenos (possibility to contribute and reuse)
<http://github.com/ParthenosWP4/standardsLibrary/blob/master/archivalDescription/EAD/ODD/EADSpec.xml>

Flexible and customizable methodology

- Very precise content oriented rules based both on EHRI and CHI input data models
- Integrating the human readable documentation in the validation process → deepen the relationship between validation and documentation

Flexible and customizable methodology



Flexible and customizable methodology

- Use ODD to create specific EAD profiles
 - Each new EAD profile = new ODD
 - Inheritance to the master source + possibility to modify the elements that have a different behaviour
- Adding more specific rules to the core EAD schema
 - EAD schema (expressed in RelaxNG)
 - ISO Schematron rules

Schematron rules

- Emphasize EAD validation errors
- Align the descriptions with EHRI constraints
- Highlight some description elements that could be improved
- Sorted in categories (roles)
 - MUST: mandatory for import process
 - SHOULD: mandatory for description process, i.e. In terms if archival description. Not technically mandatory, but may cause comprehension issues
 - COULD: non mandatory rules. Enhance the general quality of the description, without any obligation. Pointing that informational element.

Schematron rules

```
<constraintSpec ident="labelDesirable" scheme="isoschematron" type="EHRI" mode="add">
  <desc><gi>unitdates</gi> COULD have a <att>label</att> attribute or an
    <att>encodinganalog</att> attribute, describing the type of date</desc>
  <constraint>
    <rule xmlns="http://purl.oclc.org/dsdl/schematron" context="ead:unitdate"
      see="&path;#EAD.unitdate"><assert xmlns="http://purl.oclc.org/dsdl/schematron"
        role="COULD" test="normalize-space(@label) or normalize-space(@encodinganalog)"
        >unitdates COULD have a label attribute or an encodinganalog attribute,
        describing the type of date</assert></rule>
    </constraint>
  </constraintSpec>
```

Schematron rules

```
<constraintSpec ident="authfileNumberPossible" scheme="isoschematron" type="EHRI">
  <desc>Access points COULD be chosen in authority lists. The list is declared with a
    <att>source</att> attribute. The related id of this authority should be declared
    in an <att>authfileNumber</att> attribute. Note that EHRI provides URLs for
    vocabularies and authorities. Check the <ref target="http://ehri-project.eu">EHRI
    website</ref> for more information</desc>
  <constraint>
    <rule xmlns="http://purl.oclc.org/dsdl/schematron" context="ead:controlaccess"
      see="&path;#EAD.controlaccess">
      <assert xmlns="http://purl.oclc.org/dsdl/schematron" role="COULD"
        test=".[@authfileNumber and @source]">Access points COULD be chosen in an
        authority list. This list should be declared in a @source attribute. The related
        id of this authority should be declared in an @authfileNumber attribute.
      </assert>
    </rule>
  </constraint>
</constraintSpec>
```

Schematron rules

- Content normalisation (dates, codes, ...)
- Required elements in EHRI (but not in EAD)
→ scopecontent (description of the content of the documents) for instance
- Improve descriptions quality. Not errors, but pieces of advice. In particular for content related elements (existence of copies of the material, bibliographic references, ...)

Connect validation and mapping process to ad hoc documentation

A full description of the expected content (i.e. HTML “tag library”) is generated from the ODD file.

In the validation process, the documentation is served to the user in its context.


- EAD technical documentation
- EHRI technical documentation
- EHRI qualitative documentation

Connect validation and mapping process to ad hoc documentation

2.1.11. <archdesc>

<p><archdesc> (Archival Description) A wrapper element for the bulk of an EAD document instance, which describes the content, context, and extent of a body of archival materials, including administrative and supplemental information that facilitates use of the materials. Information is organized in unfolding, hierarchical levels that allow for a descriptive overview of the whole to be followed by more detailed views of the parts, designated by the element Description of Subordinate Components <dsc> . Data elements available at the <archdesc> level are repeated at the various component levels within <dsc>, and information is inherited from one hierarchical level to the next.</p>	
Namespace	http://www.tei-c.org/ns/1.0
Module	EAD
Attributes	<p>att.EADGlobal (@id, @altrender, @audience, @encodinganalog) att.relatedencoding (@relatedencoding) att.desc.c (@level, @otherlevel)</p> <p>@level The hierarchical level of the materials being described by the element.</p> <p>Derived from att.desc.c</p> <p>Status Required</p> <p>SchematronIf the attribute @level has the value 'otherlevel', an attribute @otherlevel MUST be added</p> <div> <pre> <s:rule context="ead:ead" see="https://cdn.rawgit.com/EHRI/data-validations/92c8e39f/ODD-RelaxNG/EAD/EHRI_EAD_doc.html#EAD.att.desc.c"> <s:assert role="MUST" test="not(@level = 'otherlevel') or (@otherlevel and not(@otherlevel = ''))">If the attribute level has the value 'otherlevel' MUST be added</s:assert> </s:rule> </pre> </div> <p>SchematronThe <archdesc> element can have for @level the value 'findel' not the subcomponents <c01> to <c05></p>

Workflow



Future developments

This method may be of a wider interest

1. Bridge between EAD2002 and EAD3 → soon an EAD3 ODD derived from EAD2002 ODD
2. Future maintenance of the EAD standard? in order to, like for the TEI, oriente this maintenance towards a (wise) continuous revision methodology.

Future developments

Conversion EAD → TEI

Several projects

First step: Mapping EAD <-> TEI (msDesc module)

→ Dominique Stutzmann, IRHT (Institut de recherches et d'histoires des textes) and Elena Pierrazzo, LUHCIE (Laboratoire universitaire Histoires Cultures Italie Europe)

More ambitious: extracting content from EAD with Regex, NER, ... to create structured TEI descriptions beyond what EAD can provide.

→ Jean-Baptiste Camps (École des Chartes)

Remerciements à Marie-Françoise Limon-Bonnet, et toute l'équipe du projet Lectaurep (Convention Inria-Ministère de la culture)

EXTRACTION DE D'INFORMATION À PARTIR DES RÉPERTOIRES DES ÉTUDES NOTARIALES

LECTAUREP

Lecture Automatique de Répertoires

Archives nationales (DMC/DMOASI)
Équipe ALMAAnaCH

Atelier Culture - Inria, 22 novembre 2018

Partenariat

Archives nationales

Département du Minutier Central (DMC)

Département de la maîtrise d'ouvrage du système d'information (DMOASI)


- Marie-Françoise Limon-Bonnet (DMC)
- Aurélia Rostaing (CC DMC)
- Danis Habib (CHED DMC)
- Frédéric Zamarreno (resp. DMOASI)
- Gaetano Piraino (DMOASI)

ALMAAnaCH (*Automatic Language
Modelling and Analysis and
Computational Humanities*)

Équipe-projet Inria-EPHE

- Marie-Laurence Bonhomme, stagiaire
Master TNAH de l'ENC
- Marc Bui, EPHE
- Éric de la Clergerie, Inria
- Benjamin Kiessling, EPHE
- Marie Puren, Inria
- Laurent Romary, Inria
- Charles Riondet, Inria
- Daniel Stökl Ben Ezra, EPHE

Le corpus d'archives



Le notaire, un officier public ministériel

- Détenteur d'une part de l'*auctoritas publica* ou de la foi publique,
- Producteur d'actes authentiques en forme de minutes,
- Lesquelles sont listées dans des répertoires

Le corpus d'archives

Les **répertoires des études notariales** sont des registres dans lesquels un clerc consigne, dans l'ordre chronologique et pour chaque jour, les actes qui ont été passés et enregistrés dans son étude.

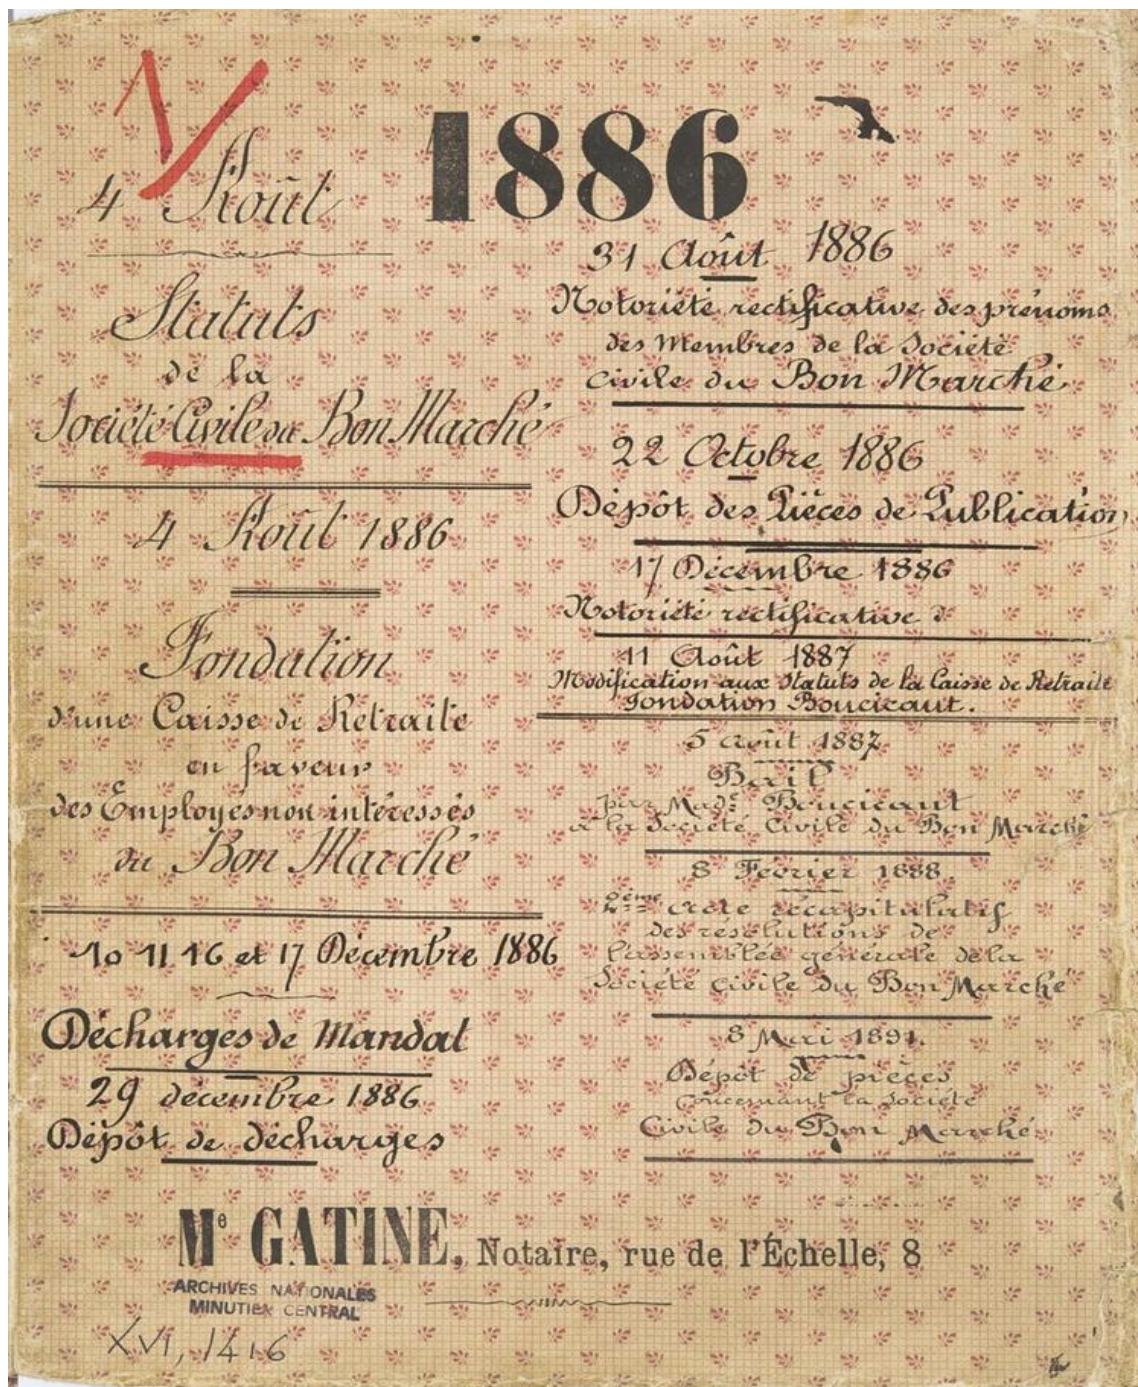
Ils doivent nécessairement contenir la **date de l'acte**, sa **nature** et son **espèce** (en minute ou en brevet*) ainsi que le **nom des parties** et la **relation de l'enregistrement**.

Un formulaire pré-imprimé à 7 colonnes.

*La minute d'un acte notarié est l'original d'un acte authentique dont le notaire ne peut se défaire ; un acte en brevet est un acte notarié dont l'original est dépourvu de formule exécutoire, et est remis aux parties.

Un exemple de
minute, les statuts de
la société civile du
« Bon Marché »

Arch. nat. MC/ET/XVI/1416



La mention de
cette même minute
- Statuts de la
société civile du
Bon Marché -
au répertoire du
notaire Gatine

[https://www.siv.archive
s-
nationales.culture.gouv
.fr/siv/media/FRAN_IR
_051822/c1ug18c3sei4
==
w32j38d5447t/DAFAN
CH96_016MIC06736
L](https://www.siv.archive.s-nationales.culture.gouv.fr/siv/media/FRAN_IR_051822/c1ug18c3sei4==w32j38d5447t/DAFAN_CH96_016MIC06736_L)

N° ET RÉPERTOIRE	DATES	NATURE ET ESPÈCE DES ACTES :		NOMS, PRÉNOMS ET DOMICILES DES PARTIES. INDICATIONS, SITUATIONS ET PRIX DES BIENS.	RELATION DE l'Enregistrement.	
		EN BREVETS.	EN MINUTES.		DATES.	DROITS.
446	?	1. du 10 juin 86	Realisation	An 1886 mois d'Avril (suite) Houmann (de prêt de 1000 francs prêt fourni à Charles Ferdinand) 11 rue Tolonin Paris		
447	3		Receissé de Cte de Butelle	Evassour / par Caroline Henriette Loe 89 rue Colbert à Paris Celestin Lougeard 11 rue des 3 bornes sans valeur date		37.10
448	3		Donation entre époux	Aroyant / par Edward Léon 1 rue Dauphine Paris à Paris à Marie Celestin Lougeard 11 rue des 3 bornes sans valeur date		37.10
449	3		Autre	Aroyant / par Louis à Paris mari		"
450	3	1. du 11 avril 1886	Dépôt de Déclaration	Commenant - Tournehambault (concernant la Ste) 16 place Vendôme Paris		"
451	3		Obligation et Prorogation de délai	Dubois / par Françoise Margte Adèle Bollet 11 rue Jules Maurice 11 rue de la Monnaie à Joseph Fois Laquelle Monin de Bollay à Limay (S. d. O.) de 10000 rebut au 10 juillet 1890 et d'obl. de 10000 du 10. 1890	6	11.40
452	3		Bail	Frot, (par Paul) 67 rue Jussieu à Jm Ste Coste de Montpellier de locaux à Paris faub. St Denis 87 et bis pour 1 an du 1 ^{er} Oct 86 moyt. 108% - 118% 14 8/10, 16 3/10, 18%	6	153.71
453	9 + 2		Procuracion	Dauvergne / par Jeanne Maria Chossonary 21 rue Bertrand 11 rue Celestin Louis) d'Lucien Celestin Louis - 71 rue Versailles à Boulogne Seine à M ^{re} Den pour Ste du Bon Marché	6	8e.40
454	6		Procuracion	Bouicaut / par Margte Guerin 11 rue Aristide Jaquer 11 rue du Nord ancien Frederic Henri Labille 11 rue de Rochelle pour faire 2 comptes promesse de 11 ^{re} d'actions	9	7.50
455	4		Donation	Bouicaut / par la même à la Société Civile du Bon Marché de 1.00000 pour fonder la caisse de retraite	9	3.71
456	4		Statuts de la Société civile du Bon Marché	Société Civile du Bon Marché 111 à Paris rue du Bon 1 ^{re} Civile par action entre M ^{re} Bouicaut et partie de ses employés pour 8 francs	9	125.000 --
457	4		Fondation	Bon Marché (par la Ste) au profit des employés de la caisse de retraite	9	508.71
458	4		Bail	Bouicaut / par la Ste au profit des employés de la caisse de retraite	9	3.71

Le corpus d'archives



AU NOM DU PEUPLE FRANÇAIS.

BONAPARTE, PREMIER CONSUL,
PROCLAME loi de la République le décret suivant, rendu par le
Corps législatif le Vingt-neuf Ventôse, an six, conformément à la
proposition faite par le Gouvernement le quatre-vingt-neuf messidor
communiquée au Tribunat le six cent quatre-vingt-neuf.

DÉCRET

Titre 1er

Des Notaires et des actes notariés.

Section 1re

Des fonctions, attributions et droits des Notaires.

Article 1er

Les Notaires sont les fonctionnaires publics
établés pour recevoir tous les actes et contrats auxquels
les parties doivent ou veulent faire donner le caractère
d'authenticité attaché aux actes de l'autorité publique,
et pour en assurer la date, en conserver le dépôt, en délivrer
les protocoles et expéditions.

Depuis 1803 (25 ventôse an XI art. 29-30), le
répertoire est « normalisé » et enrichi dans ses
contenus

Projet LECTAUREP ⇒ Section du corpus

Entre 1803 et 1940, un corpus (rien qu'à Paris)
de 917 notaires différents, env. 1800 registres

Le corpus d'archives

Le Minutier central des notaires de Paris, créé en 1928 au sein des Archives nationales. Il a pour vocation de conserver les fonds des 122 études notariales historiques de la capitale :

- 20 millions de minutes
- 3 300 répertoires
- 172 000 liasses et registres

⇒ 26 000 mètres linéaires.

RECHERCHER ▾ RECHERCHE AVANCÉE

Salle des inventaires virtuelle

PARCOURIR LES FONDS ▾ PRODUCTEURS D'ARCHIVES

Rechercher

▸ Tous les mots saisis

Toutes les archives Archives numérisées Producteurs d'archives

SÉLECTIONNER DES CRITÈRES

CRITÈRES SÉLECTIONNÉS : Producteur : Mocquard, Constant Amédée (1815-1889) x

Modifier ma recherche +

Trier par ▾ Pertinence

☒ Résultats groupés par inventaires Voir : 15 30 45

2 résultats dans 2 inventaires.

INVENTAIRE ⓘ Cote(s) : MC/ET/LXVIII/1054 - MC/ET/LXVIII/1281, MC/RE/LXVIII/16 - MC/RE/LXVIII/17

Minutes et répertoires du notaire Constant Amédée MOCQUARD, 12 juillet 1853 - 21 juillet 1875 (étude LXVIII)

Producteur(s) : Mocquard, Constant Amédée (1815-1889) Etude LXVIII

[Voir le résultat](#)

Voir l'inventaire

Voir tous les résultats dans l'inventaire

INVENTAIRE ⓘ Cote(s) : MC/RE/LXVIII/16 - MC/RE/LXVIII/17

Images des répertoires du notaire Constant Amédée Mocquard pour l'étude LXVIII

Producteur(s) : Etude LXVIII Mocquard, Constant Amédée (1815-1889)

[Voir le résultat](#)

Voir l'inventaire

Salle des inventaires virtuelle des Archives nationales :

Répertoires numérisés en ligne en mode image pour l'Ancien Régime comme pour le XIX^e et le premier XX^e.

N°	DATES	NATURE ET ESPECE		NOMS, PRENOMS ET DOMICILES DES PARTIES	RELATION	
		DES ACTES :			de	
					l'Enregistrement.	
REPERTOIRE	ACTES	EN BREVETS	EN MINUTES	INDICATIONS, SITUATIONS ET PRIX DES BIENS	DATES	DROITS
804	13	Augmentation		An 1920, mois d'Avril Brugniere (par Rose Suzanne Gauthier, v ^e D ^{re} Francis Louis) - Gaius rue Michel Ange 84, - Blanc, pour tombeau	15	3.75
805	13	Donation		de Vaugrigneuse (par Jeanne Charles Edmond) D ^{re} Thias, avenue Hecker 13, - Gaius avec Esther Tassel - femme (cont. pp ^{te})	"	"
806	13	Donation		de Vaugrigneuse (par Gaius) - Gaius Tassel, sur - Gaius et son mari (cont. pp ^{te})	"	"
807	13	C ^{te} de mariage		Liensmann (cont. Henri Théophile Louis) - Gaius rue Beauregard 26, - Gaius avec Gierat, D ^{re} - Gaius rue Montpessier 32 C ^{te} d'acquisition	15	177.93
808	14	Augmentation		Halberci (par Louis Eugène Albert) D ^{re} - Gaius rue Rambuteau 116, en blanc, pour radier inscript.	15	3.75
809	14	C ^{te} de pp ^{te}		Haas (cont. Louis Camille Elpargue 75-3214319) au nom de, Corvathal Lina, femme de M. Haas, en son vivant, D ^{re} - Ventes de Bois g. - L. 250 f	16	"
810	14	maintenue		Rodeo (par Antoine) - Gaius rue Gallien 10 par - et actual. rue D ^{re} Lages 13 d'inscript. au D ^{re} de commune - le 30 mai 1919 v ^e 8615 cont. Commis		

Ressource riche mais difficile d'accès

Depuis le XVI^e siècle, le répertoire est donc un registre qui liste, pour chaque jour, les actes passés dans une étude donnée...

... Pour exploiter ces répertoires, il faut toujours en passer par un dépouillement systématique parfois long

... Il n'en existe pas de transcription, pas de possibilité de recherche en plein texte

Objectifs du projet

- Offrir un meilleur accès à cette ressource
- Possibilité pour les chercheurs de réaliser des exploitations statistiques et quantitatives, en considérant ces répertoires non plus comme des inventaires mais comme des sources primaires.

Approche

- Reconnaissance automatique de structures et d'écriture manuscrite
- Mise à disposition des images numérisées de ces répertoires et de leur transcriptions sur une plateforme en ligne permettant d'y effectuer des recherches avancées.

Éléments de méthode

Segmentation des tableaux

- Distinction des classes d'information
- Analyse des répétitions de structures

HTR (Handwritten Text Recognition)

- Scribes multiples
- Utilisation de ressources sémantiques (référentiels des Archives Nationales)

Vers la conception d'une chaîne de traitement

1. Layout analysis : analyse de la structure physique et sémantique des répertoires
2. Reconnaissance d'écriture manuscrite
3. Extraction d'informations (Personnes, Lieux)
4. Brique participative (Correction des transcriptions, annotation)
5. Intégration dans le Système d'information des Archives Nationales
6. Mise à disposition de la communauté des chercheurs

Phase 1 du projet

Accent mis sur les premières étapes de la chaîne de traitement

1. **Layout analysis : analyse de la structure physique et sémantique des répertoires**
2. **Reconnaissance d'écriture manuscrite**
3. *Extraction d'informations (Personnes, Lieux)*
4. *Brique participative (Correction des transcriptions, annotation)*
5. *Intégration dans le Système d'information des Archives Nationales*
6. *Mise à disposition de la communauté des chercheurs*

Layout analysis (structure
de la page)

La segmentation des actes

N° DU REPERTOIRE	DATES DES ACTES	NATURE ET ESPÈCE DES ACTES :		NOMS, PRÉNOMS ET DOMICILES DES PARTIES INDICATIONS, SITUATIONS ET PRIX DES BIENS	RELATION DE l'Enregistrement.	
		EN BREVETS	EN MINUTES		DATES	DROITS
1654	27	Procuration		An 1919, mois de Novembre Noël, (par Linné) 5 ^e à Gaimme de la montagne St Genevieve 47, en blanc, pour rembourser son Bas (cont. armoire) courus au duc de Jh. Etienne Guillaume) duc de son domicile à Gaimme, Laconjuncte le 27 avril 1919 au rentier pour l'acte n° 1325777 et 1636220 de 100 ^e chacun	29	3.75
1655	27	Cat. de pp ^{te}				
1656	27	Cat. de vie		Grimbert, (de la p ^{re} Sylvie Pinot épouse de Grimbert, (de la p ^{re} Sylvie Pinot épouse de Grimbert, (de la p ^{re} Sylvie Pinot épouse de	26	1.88

Structure du tableau dans le registre :

- Imprimé
- Lignes verticales
- Cohérent sur tout le corpus

Structure de l'acte :

- Manuscrit
- Plusieurs mains
- Pas de lignes horizontales
- Alignement aléatoire

La reconstitution des actes

Vide (sauf accident dans colonnes adjacentes)

1654	27	Procuration	An 1919, mois de Novembre		
1655	27	Col de ppte	Noël, (par l'intermédiaire) St. à l'origine de la montagne St. Genevieve 47, en blanc, pour rembourser son Bas (cont. à l'origine, courus au d'éc. de St. Etienne Gintheau) d'éc. en son domicile à l'origine, l'origine le 27 avril 1919 sur rente viagère pour l'origine n° 1325777 et 1636220 de 100° chacun	29	3.75

N° de l'acte
Nombre entre 1 et
3000 (estimation)

Typologie de l'acte
Chaîne de caractère
Vocabulaire contrôlé

Date de l'acte (jour)
Nombre entre 0 et 31

Date d'enregistrement (jour)
Nombre entre 0 et 31

Date de l'acte (année et mois)
Écritures mixtes (imprimées et manuscrites)

Description de l'acte
Nom et adresse des signataires, prix de vente d'un bien,
date d'un décès, etc.

Taxes acquittées
Chiffres, chaînes de
caractères (gratis,
etc.)

Segmentation automatique de la page, de l'entête et des colonnes

N°	DATE	NATURE ET PAPER DE L'ÉCRITURE		NOMS, PRÉNOMS ET DOMICILES DES ÉCRIVAINS	ABRÉGÉS	
		ÉTENDUE	ÉTENDUE		ÉTENDUE	ÉTENDUE
				AN 1787, mois de Mars		
101	1787	1787	1787	AN 1787, mois de Mars	1	7.1
102	1787	1787	1787	AN 1787, mois de Mars	1	7.1
103	1787	1787	1787	AN 1787, mois de Mars	1	7.1
104	1787	1787	1787	AN 1787, mois de Mars	1	7.1
105	1787	1787	1787	AN 1787, mois de Mars	1	7.1
106	1787	1787	1787	AN 1787, mois de Mars	1	7.1
107	1787	1787	1787	AN 1787, mois de Mars	1	7.1
108	1787	1787	1787	AN 1787, mois de Mars	1	7.1
109	1787	1787	1787	AN 1787, mois de Mars	1	7.1
110	1787	1787	1787	AN 1787, mois de Mars	1	7.1
111	1787	1787	1787	AN 1787, mois de Mars	1	7.1
112	1787	1787	1787	AN 1787, mois de Mars	1	7.1
113	1787	1787	1787	AN 1787, mois de Mars	1	7.1
114	1787	1787	1787	AN 1787, mois de Mars	1	7.1
115	1787	1787	1787	AN 1787, mois de Mars	1	7.1
116	1787	1787	1787	AN 1787, mois de Mars	1	7.1
117	1787	1787	1787	AN 1787, mois de Mars	1	7.1
118	1787	1787	1787	AN 1787, mois de Mars	1	7.1
119	1787	1787	1787	AN 1787, mois de Mars	1	7.1
120	1787	1787	1787	AN 1787, mois de Mars	1	7.1
121	1787	1787	1787	AN 1787, mois de Mars	1	7.1
122	1787	1787	1787	AN 1787, mois de Mars	1	7.1
123	1787	1787	1787	AN 1787, mois de Mars	1	7.1
124	1787	1787	1787	AN 1787, mois de Mars	1	7.1
125	1787	1787	1787	AN 1787, mois de Mars	1	7.1
126	1787	1787	1787	AN 1787, mois de Mars	1	7.1
127	1787	1787	1787	AN 1787, mois de Mars	1	7.1
128	1787	1787	1787	AN 1787, mois de Mars	1	7.1
129	1787	1787	1787	AN 1787, mois de Mars	1	7.1
130	1787	1787	1787	AN 1787, mois de Mars	1	7.1
131	1787	1787	1787	AN 1787, mois de Mars	1	7.1
132	1787	1787	1787	AN 1787, mois de Mars	1	7.1
133	1787	1787	1787	AN 1787, mois de Mars	1	7.1
134	1787	1787	1787	AN 1787, mois de Mars	1	7.1
135	1787	1787	1787	AN 1787, mois de Mars	1	7.1
136	1787	1787	1787	AN 1787, mois de Mars	1	7.1
137	1787	1787	1787	AN 1787, mois de Mars	1	7.1
138	1787	1787	1787	AN 1787, mois de Mars	1	7.1
139	1787	1787	1787	AN 1787, mois de Mars	1	7.1
140	1787	1787	1787	AN 1787, mois de Mars	1	7.1
141	1787	1787	1787	AN 1787, mois de Mars	1	7.1
142	1787	1787	1787	AN 1787, mois de Mars	1	7.1
143	1787	1787	1787	AN 1787, mois de Mars	1	7.1
144	1787	1787	1787	AN 1787, mois de Mars	1	7.1
145	1787	1787	1787	AN 1787, mois de Mars	1	7.1
146	1787	1787	1787	AN 1787, mois de Mars	1	7.1
147	1787	1787	1787	AN 1787, mois de Mars	1	7.1
148	1787	1787	1787	AN 1787, mois de Mars	1	7.1
149	1787	1787	1787	AN 1787, mois de Mars	1	7.1
150	1787	1787	1787	AN 1787, mois de Mars	1	7.1

- + tableau et images constants
- la page peut-être en rotation

étapes

- détection de lignes horizontales et verticales du tableau (à l'aide de transformations morphologiques et de composantes connectés)
- détection et correction de la rotation de la page
- segmentation de la page de l'arrière-fond
- segmentation en colonnes et entête de la page
- suppression des séparateurs du tableau

Segmentation verticale des lignes et des actes

The image shows a handwritten document with two rows of text. The first row is highlighted with a red box, and the second row is highlighted with a blue box. Arrows point from these boxes to a legend at the bottom of the image.

1654	27	Procuration	An 1919, mois de Novembre Noël, (par Lamine) 1 ^{er} à l'origine de la montagne St Genevieve 47, en blanc, pour rembourser son	29	3.75
1655	27	Col d'App	Dad (conc. mine) couru au duc de St. Genevieve Guillaume) duc de son domaine à l'origine de la montagne le 27 avril 1919 sur rente viagère pour l'entretien n° 1325777 et 1636220 de 100 ^{es} chacun	"	"

Début de l'acte
écriture à la première ligne de l'acte

Colonne centrale : Description de l'acte
zone avec écriture intensive. lignes remplies

Fin de l'acte
écriture à la dernière ligne de l'acte

Indices de segmentation

1654	27	Progeniture	<p>An 1919, mois de Novembre</p> <p>Noël, (par Linné) 5^e à Gaius, rue de la montagne</p> <p>St Genevieve 47, en blanc, pour recueillir son</p> <p>Bas (cane + mince, comme au lieu de J. H. de</p> <p>Gintheaux) d'écarter son domicile à Gaius, L'assommoir</p> <p>Le 27 avril 1919 au rentier vagin pour l'écarter</p> <p>N^o 1325777 et 1636220 de 100^e chaux</p>	29	3.75
1655	27	Cat lepp ^{te}			


Limite supérieure de l'acte:

- *N° d'ordre*
- *Date de l'acte*
- *Typologie*
- *Nom du signataire en gras*

Limite inférieure de l'acte:

- Description de l'acte: dernière ligne parfois incomplète
- Date de l'enregistrement de l'acte
- Taxes acquittées

Segmentation automatique des lignes



An 1920, mois de janvier
Favret (par G. Eugène Ambroise) R. à G. rue
Coppel, 6, à Richard René Germain Richardseau
et Jules Bach, s'af. à Chelillon sous Boqueron, rue de la
Main 34, de la rue à G. rue Coppel, 6, à compter du
5 janvier 1920. Loyer 1400.
Petit (par Charles Lém) et Félixine Eugène Beaudouin
s'af. à G. rue de Laguy 5 à Louis Maurice Réve
R. à Chimon (Jules René) par G. rue de Laguy 5
hangar à usage de lavoir, à G. rue de Laguy 5
(ancien 3) et vendu par l'ad. jr. à dame Petit 6 de Réve
du dit lavoir moy. 25000 - payable à raison de 3000
par an net à 5% à partir du 1^{er} octobre 1919
13

Seamcarving (chemin d'énergie minimale) pour segmenter les lignes de la colonne de description de l'acte.

Extension de la segmentation des lignes au reste du tableau

N°	DATES		NATURE ET ESPÈCE		NOMS, PRÉNOMS ET DOMICILES DES PARTIS	RELATION	
	AN	MOIS	DES MOIS			TÉMOIGNAGE	
			AN RÉVÉLÉ	AN RÉVÉLÉ		AN	MOIS
					INDICATIONS, CITATIONS ET PRIÉ DES BESOINS		
					An 1870, mois de Janvier		
59	1870	Jan			...	12	3.1.71
60	1870	Jan			...		
61	1870	Jan			...		
62	1870	Jan			...		
63	1870	Jan			...		
64	1870	Jan			...		
65	1870	Jan			...		
66	1870	Jan			...	13	1.1.71
67	1870	Jan			...		
68	1870	Jan			...	16	6.1.71
69	1870	Jan			...		

Bons résultats en général:
Alignements horizontaux parfois
décalés

Difficultés de segmentation

Présence d'un obstacle (tampon) dans la colonne 2 ⇒
Numéro de l'acte décalé dans la marge (colonne 1)

N ^o	DATES	NATURE ET ESPÈCE DES ACTES :		NOMS, PRÉNOMS ET DOMICILES DES PARTIES INDICATIONS, SITUATIONS ET PRIX DES BIENS	RELATION DE l'Enregistrement.	
		EN BREVETS	EN MINUTES		DATES	DROITS
43	8			<p>An 1920, mois d. Janvier</p> <p>Talbert (par Lucien Talbert) et sa femme Roussaint, dem^r à Mendon, rue des Vignes 31, d'un appartement au 2^e de c^t de la 3^e mi le 11 9^e 1909. N^o 13459. contre un n^o Gabriel. Des annuaires St. i. choisy le Roi, avenue St. Hugo, 29</p>	9	7.38

Difficultés de segmentation

- Dépassement du texte sur plusieurs colonnes
- Ruptures textuelles aussi lors des mentions introductives ou légales du juge

30	6	Constitution de requête	Jossilevitch C des 30000 fr. payés comptant sur le prix de vente par les h ^{rs} Ladrille, répertorié n° 28 qui précède.	8	3.75
31	7	C ^{te} Devie	Verifie! le présent répertorié contenant depuis le dernier visa l'inscriptio de L ^{re} Cest vingt huit actes, - d. c. r. - Paris le 7 janvier 1920, fol 4 c 17. Paris	8	1.88

Reconnaissance d'écriture manuscrite



HTR et Classification

1. Classification par reconnaissance de formes
 - Colonnes de chiffres ou de nombres
 - Dates
 - N° d'actes
 - Taxes
 - Colonnes de texte « simple » des types d'actes
2. HTR : Obtention de données d'entraînement pour construire un modèle de reconnaissance
 - Transcription collaborative d'une cinquantaine de pages avec *Transkribus* d'un répertoire de l'étude Marotte (importation des images numérisées, segmentation, transcription cellule par cellule)

Classification

Classifications par reconnaissance de formes

- Chiffres (notamment numéros de jour) : 98,66 % de précision (pour les chiffres de 0 à 9) grâce à un algorithme de classification basé un réseau de neurones convolutif



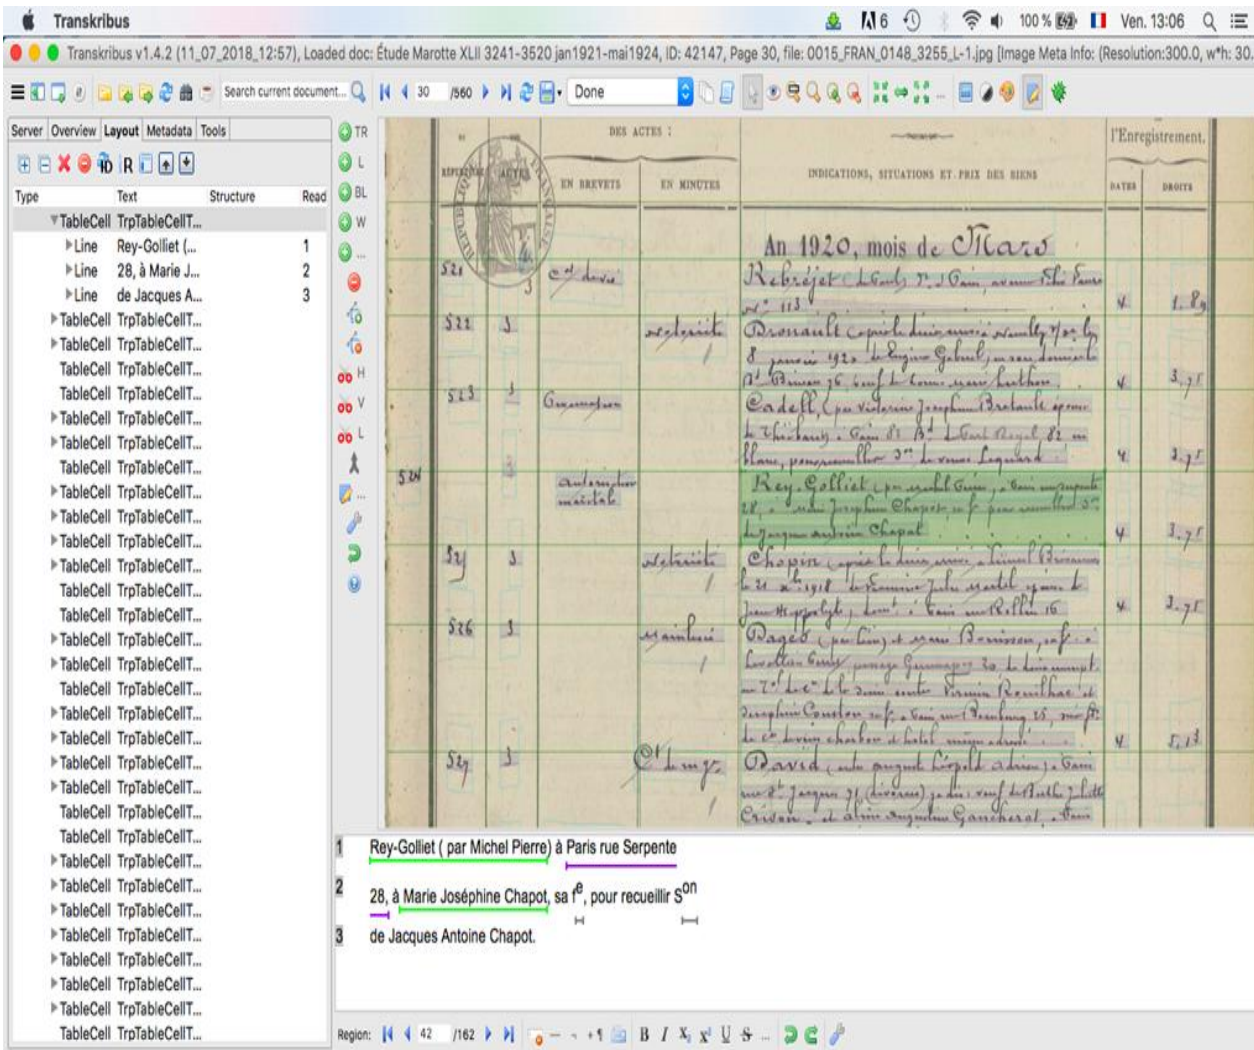
Classification

Typologies d'actes : Premier travail de classification manuelle à poursuivre. Difficultés :

- Hétérogénéité des formes
- Typologies multiples pour un acte
- Typologie absente (quand un acte est la "suite" d'un premier acte)

Problèmes	Forme "normalisée"	Variation(s)	
Formes hétérogènes	Contrat conditionnel	<i>Ct conditionel</i>	<i>Contt condel</i>
	Contrat de mariage	<i>Ct de mariage</i>	<i>Ct de mge</i>
Types multiples	Liquidation	<i>Liquidation et partage</i>	<i>Liquidation et présentation de compte de tutelle</i>
Acte faisant suite à un 1 ^{er}	Suite de l'acte du 15 décembre 1919	<i>Ste 15 xbr 1919</i>	

HTR: Acquisition des données d'entraînements (transcription et annotation)



Transkribus.eu

- Facile d'utilisation
- Travail collaboratif
- Formats d'export variés
- Customisation faible
- Pas de maîtrise du stockage des données et des modèles entraînés
- Modèles non open-source
- Futur incertain

HTR: Entraînement et premiers résultats

- Entraînement d'un modèle HTR à partir des pages transcrites manuellement "*vérité terrain*" (un seul scribe) :
 - M1 : 40 pages
 - M2 : 50 pages (1 million de mots)
- Character Error Rate (CER) sur un échantillon test du même répertoire:
 - M1 : **13,5 %**
 - M2 : **10,4 %**

⇒ ce qui reste considérable, mais peut être amélioré
- Le modèle M2 a été testé sur quelques pages d'autres registres et donc d'autres mains. Les résultats ne sont naturellement pas bons (CER autour de 40 %) : nécessité de données d'entraînement plus hétérogènes.


Défis de la phase 2

- Acquisition d'autres données d'entraînement pour d'autres mains, d'autres périodes et créer un modèle mixte
- Passage en production
 - ⇒ Envisager une plateforme de transcription collaborative
 - ⇒ Collaboration avec le projet SCRIPTA-PSL (transcription automatique de manuscrits historiques multilingues)
 - ⇒ Utilisation du logiciel d'HTR [Kraken](#) (Benjamin Kiessling, ALMAAnaCH) pour plus de contrôle et d'autonomie
- Utilisation des données sémantiques
 - ⇒ Référentiels spécifiques au corpus : typologie des actes, terminologie notariale
 - ⇒ Référentiels d'autorités pour les entités nommées (personnes et lieux : utilisation d'annuaires)
- Expérimentation sur les répétitions (word spotting)


Remerciements à Patrice Lopez, Luca Foppiano

STRUCTURATION AUTOMATIQUE DE CONTENUS

Aller au delà des données primaires non structurées (PDF)



Cow (structured data)



Hamburger
(unstructured data)

“Converting PDF to XML is a bit like converting hamburgers into cows. You may be best off printing it and then scanning the result through a decent OCR package.”

Michael Kay (<http://lists.xml.org/archives/xml-dev/200607/msg00509.html>)

Inspired from: Duncan Hull

Getting acquainted to GROBID

GROBID (GeneRation Of Bibliographic Data) (*Lopez et al. 2015*)

- Cascading content extraction from PDF
- CRF: Conditional Random Fields
- TEI: corpus annotation and final output



Example: GROBID for meta-data extraction

- GROBID (GeneRation Of Bibliographic Data) (*Lopez et al. 2015*)

Depth-resolved analysis of spontaneous phase separation in the growth of lattice-matched AlInN

title

A. Redondo-Cubero^{1,2,*}, K. Lorenz³, R. Gago⁴, N. Franco³, M.-A. di Forte Poisson⁵, E. Alves³ and E. Muñoz¹

authors

- 1 ISOM and Dpt. de Ingeniería Electrónica, ETSI Telecomunicación, Universidad Politécnica de Madrid, E-28040 Madrid, Spain.
- 2 Centro de Micro-Análisis de Materiales, Universidad Autónoma de Madrid, E-28049 Madrid, Spain.
- 3 Instituto Tecnológico e Nuclear, Estrada nacional 10, 2686-953 Sacavém, Portugal.
- 4 Instituto de Ciencia de Materiales de Madrid (CSIC), E-28049 Madrid, Spain.
- 5 Thales Research & Technology/TIGER, 91461 Marcoussis Cedex, France.

affiliation

ABSTRACT:

We report the detection of phase separation of an Al_{1-x}In_xN/GaN heterojunction grown close to lattice matched conditions (x~0.18) by means of Rutherford backscattering spectrometry in channeling geometry and high resolution x-ray diffraction. An initial pseudomorphic growth of the film was found, with good single crystalline quality, the

abstract

Grobid
About **TEI** PDF Patent Admin Doc

Service to call

☒ Consolidate
Laurent Romary, Mike Mertens, Anne Balliot. Data fluidity in DARIAH – pushing the agenda forward. BIBLIOTHEK Forschung und Praxis, De Gruyter, 2016, 39 (3), pp.350-357. <hal-01285917v2>

```
<bibliStruct >
<analytic>
<title level="a" type="main">Data fluidity in DARIAH & pushing the agenda forward</title>
<author>
<persName
xmlns="http://www.tei-c.org/ns/1.0" coords="">
<forename type="first">Laurent</forename>
<surname>Romary</surname>
</persName>
</author>
<author>
<persName
xmlns="http://www.tei-c.org/ns/1.0" coords="">
<forename type="first">Mike</forename>
<surname>Mertens</surname>
</persName>
</author>
<author>
<persName
xmlns="http://www.tei-c.org/ns/1.0" coords="">
<forename type="first">Anne</forename>
<surname>Balliot</surname>
</persName>
</author>
</analytic>
<monogr>
<title level="j">BIBLIOTHEK Forschung und Praxis</title>
<imprint>
<biblScope unit="volume">39</biblScope>
<biblScope unit="issue">3</biblScope>
<biblScope unit="page" from="350" to="357" />
<date type="published" when="2016" />
</imprint>
</monogr>
</bibliStruct>
```

Bibliographic
reference

From GROBID to GROBID-Dict

- Numerous projects dealing with legacy (unstructured) dictionaries
 - Monolingual, Bilingual
 - Old, modern
 - Cf. Borchmann et alii, Widmann & Buchanan
- Possible transition?
 - Costly manual and rule based techniques
 - Machine Learning (ML)
- Need for exchangeable lexical resources (LR)s
 - TEI...

Approach

• Cascading extraction models

• Using a univocal TEI format

• Taking into account the standardisation context:

– Towards a terser TEI subset

– TEI-Lex 0, ISO 24613-1

– Highlights:

• No (less) <entryFree>, <superEntry>

• Reduced number of elements to encode a Lexical Entry (LE)

• ...


CON

concordant, **e** adj. Qui s'accorde ; *témoinages concordants*.
concordat [kɔ̃kɔʁda] n. m. (lat. *concordatum*). Traité entre le pape et un gouvernement sur les affaires religieuses. || *Dr.* Accord entre le commerçant qui, ayant déposé son bilan, a été admis par le tribunal de commerce au règlement judiciaire et ses créanciers.
 Les plus anciens concordats sont le concordat de Worms (1122), entre Calixte II et Henri V ; le concordat de 1516, entre Léon X et François I^{er}. Le concordat entre Bonaparte et Pie VII, conclu le 16 juillet 1801, a réglé les rapports de la France avec le Saint-Siège, et de l'État avec l'Église jusqu'à la loi du 9 décembre 1905. Au xix^e s. et au xx^e s., de nombreux concordats furent signés par les papes.
concordataire adj. Relatif à un concordat : loi concordataire. || *Dr.* Se dit du commerçant qui a obtenu un concordat.
concorde n. f. (lat. *concordia*). Accord des sentiments et des volontés : rétablir la concorde entre les citoyens.
concordeur [kɔ̃kɔʁdœʁ] v. t. (lat. *concordare*). Avoir des rapports de similitude, de correspondance : dates qui concordent.
concurrent, **e** adj. Qui converge vers un même point, un même but : droites concurrentes.
conscience n. f. (du lat. *conscientia*, désirer). Penchant à jouir des biens terrestres, particulièrement des plaisirs sensuels.
conscient [kɔ̃skjɛ̃] adj. Qui exprime la conscience : regards conscients. Attaché aux plaisirs sensuels.
concurrentement [kɔ̃skjɛ̃tɑ̃] adv. Par concurrence. || Par un concours mutuel, de concert : agir concurrentement avec quelqu'un.
concurrance n. f. Rivalité entre plusieurs personnes qui visent un même but : entrer en concurrance avec quelqu'un. Rivalité d'intérêts entre commerçants ou industriels qui tentent d'attirer à eux la clientèle par les meilleures conditions de prix, de qualité, etc. • Régime de libre concurrance, système économique qui ne comporte aucune intervention de l'État en vue de limiter la liberté de l'industrie et du commerce, et qui considère les coalitions de producteurs comme des délits. || — Jusqu'à la concurrance de loi, voir. Jusqu'à la somme de concurrance v. t. (concurrance) v. t. Faire concurrance à.
concurrer [kɔ̃skjɛ̃ʁ] v. t. (concurrance) v. t. Qui tend au même but : une action concurrer. || Personne qui participe à un concours, à une compétition : les concurrents.
condenser [kɔ̃dɑ̃sɛ] v. t. (lat. *condensare*, rendre épais). Rendre plus dense, réduire à un moindre volume. || Liquéfier un gaz par refroidissement ou compression : le froid condense la vapeur d'eau. Fig. Exprimer d'une manière concise, en peu de mots :
condemner [kɔ̃dɑ̃mɛ] v. t. (lat. *condemnare*). Prononcer un jugement contre un plaideur ou un inculqué : condamner un criminel. || Astréindre, réduire à : condamner au silence, à l'immobilité. || Désapprouver, bâmer : condamner une opinion, un usage. || Interdire : la loi condamne la bigamie. || Déclarer perdu, incurable : les médecins l'ont condamné. || Barreter, moter : condamner une porte.
condensable adj. Qui peut être condensé, réduit à un moindre volume.
condensateur v. m. Phys. Appareil servant à emmagasiner une charge électrique : la bouteille de Leyde est un condensateur électrique. || Lentille servant à éclairer un objet dont on veut former une image.
condensation n. f. Action de condenser ou effet qui en résulte. || Liquéfaction d'un gaz. || Soudure de plusieurs molécules chimiques, avec élimination d'eau.
condensé n. m. Résumé d'une œuvre littéraire.
condenser [kɔ̃dɑ̃sɛ] v. t. (lat. *condensare*, rendre épais). Rendre plus dense, réduire à un moindre volume. || Liquéfier un gaz par refroidissement ou compression : le froid condense la vapeur d'eau. Fig. Exprimer d'une manière concise, en peu de mots :

GROBID-Dictionaries: LI Processing




CRF model



Segmented Page




CRF model



Segmented Page




CRF model




Segmented LE



CRF models



Segmented form/sense



CRF model

Orkney Scots dictionary

chap v. 1 knock, *'He chappid fower or five times at the door and got no reply.'* 2 mash potatoes, *'I like me tatties chappid.'* 3 chop wood, *'Ah'll go and chap twa three sticks for the fire.'*
chappeen tree potato masher.

<entry>

<form type="lemma">

<orth>chap</orth>

</form>

<gramGrp><pos>v.</pos></gramGrp>

<sense>

<sense>1 knock, *'He chappid fower or five times at the door and got no reply.'*</sense>

<sense>2 mash potatoes, *'I like me tatties chappid.'*</sense>

<sense>3 chop wood, *'Ah'll go and chap twa three sticks for the fire.'* chappeen tree potato masher</sense>

</sense>

</entry>

Mueller (1878) (“Etymologisches Wörterbuch der englischen Sprache”, 2nd ed., Cöthen 1878/1879)

Cabbage 1. *kohl*; *altengl.* *cabage*, *bei* *Hal.* 226 *cabes*, *cabishes*; *mlat.* *gabusia*, *fr.* *cabus*, *it.* *cappuccio*; *vgl.* *ndl.* *cabuis*, *cabuyscoole*, *nhd.* *kappes*, *worüber* *Weigand* 1, 562: „*Im* vocab. incip. teut. ante *lat.* *kabbas*, *mhd.* *der kapa3*, *kape3*, *spätahd.* *kabu3*, *capu3*. *Aus fr.* *der cabus*, *it.* *capuccio*, *welches wie russ.* *die kapusta kohl*, *aus mlat.* *caputium kapuze* *hervorging und der geschlossene kohl schien einer mönchskappe ähnlich*;“ *vgl.* *Diez* 1, 110 *und unter den nhd.* *kabisz*, *kabis* *Grimm* 5, 9.

```
<entry>
  <form>
    <orth>Cabbage</orth><label>1.</label>
  </form>
  <etym>
    <seg><def>kohl</def>;<lang>altengl.</lang>
      <mentioned>cabage</mentioned>, <seg>bei</seg>
      <bibl>Hal. 226</bibl><mentioned>cabes</mentioned>,
      <mentioned>cabishes</mentioned>; <lang>mlat.</lang>
      <mentioned>gabusia</mentioned>, <lang>fr.</lang>
      <mentioned>cabus</mentioned>, <lang>it.</lang>
      <mentioned>cappuccio</mentioned>;
      <seg>vgl.</seg><lang>ndl.</lang>
      <mentioned>cabuis</mentioned>,
      <mentioned>cabuyscoole</mentioned>, <lang>nhd.</lang>
      <mentioned>kappes</mentioned>, <seg>worüber</seg>
      <bibl>Weigand 1, 562</bibl>;
    </seg>
    <quote>„Im <bibl>vocab. incip. teut.</bibl> ante
      <lang>lat.</lang> <mentioned>kabbas</mentioned>,
      <lang>mhd.</lang> der <mentioned>kapa3</mentioned>,
      <mentioned>kape3</mentioned>, <lang>spätahd.</lang>
      <mentioned>kabu3</mentioned>,
      <mentioned>capu3</mentioned>. Aus <lang>fr.</lang>
      der <mentioned>cabus</mentioned>, <lang>it.</lang>
      <mentioned>capuccio</mentioned>, welches wie
      <lang>russ.</lang> die <mentioned>kapusta</mentioned>
      <def>kohl</def>, aus <lang>mlat.</lang>
      <mentioned>caputium</mentioned> <def>kapuze</def>
      hervorging und der geschlossene kohl schien einer
      mönchskappe ähnlich;“
    </quote>
    <seg><seg>vgl.</seg> <bibl>Diez 1, 10</bibl>
      <seg>und unter den</seg> <lang>nhd.</lang>
      <mentioned>kabisz</mentioned>,
      <mentioned>kabis</mentioned> <bibl>Grimm 5, 9</bibl>.
    </seg>
  </etym>
</entry>
```

Projet Dopamine

EPILOGUE: TRACER LES DONNÉES D'EXPÉRIENCE

Un contexte national et européen

« pressant »

- Le Plan national pour la science ouverte – juillet 2018
 - « Rendre obligatoire la diffusion ouverte des données de recherche issues de programmes financés par appels à projets sur fonds publics »
 - « La France recommandera l'adoption de licences ouvertes pour les publications et les données »
- De nombreuses initiatives européenne
 - Publications ouvertes : OpenAire, Plan S
 - Données
 - Obligation de la production d'un plan de gestion de données, pression pour disposer de données « FAIR »
 - RDA, GO FAIR, mise en place d'EOSC
 - Infrastructures européennes de la feuille de route ESFRI: DARIAH, E-RIHS, CLARIN, OPERAS, DiSSCo

Expérience acquise dans le cadre d'Iperion CH

- Iperion CH
 - Integrated Platform for the European Research Infrastructure ON Cultural Heritage
 - INFRAIA-1-2014-2015 - Integrating and opening existing national and regional research infrastructures of European interest
 - 19 équipements, dans 11 pays regroupés au sein de 3 plates-formes: ARCHLAB, FIXLAB and MOLAB
- Enquêtes effectuées au sein de la tâche 2.2 *Management plan of generated digital data*
 - Collaboration avec IPANEMA

Enquête Iperion CH – principaux résultats

- Double enquête sur les pratiques et les jeux de données
 - excellente couverture du consortium
 - 3 plates-formes et 29 instruments, 78 jeux de données mentionnées couvrant une très grande variété de matériaux et de méthodes d'analyse
- Difficultés exprimées par les répondants
 - documentation des données
 - formats standards et réutilisables
 - hébergement informatique pérenne
 - licences associées aux jeux de données

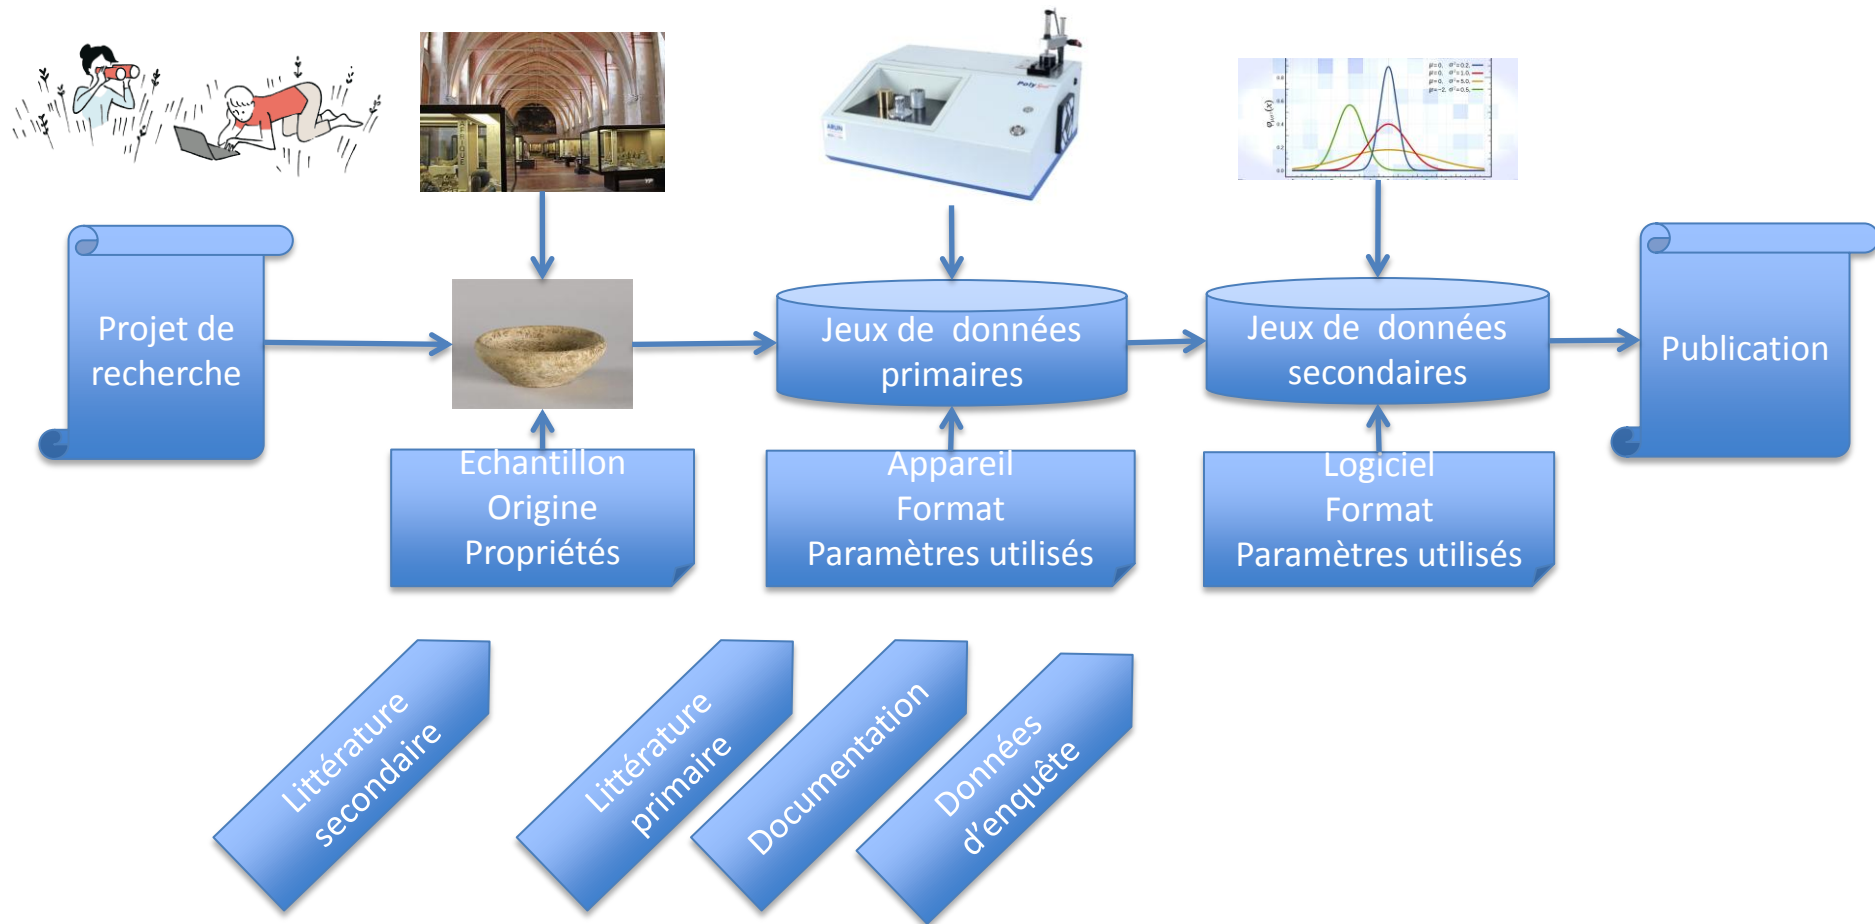
Et le chercheur/la chercheuse dans tout ça ?

- Recentrer le débat sur l'individu et le projet de recherche
 - Les principes FAIR sont trop centrés sur les jeux de données, mais pas sur les acteurs du processus de recherche
 - L'administration des données ne doit pas prendre le pas sur la recherche elle-même
- Identifier les questions qui peuvent se poser sur le terrain
 - Documentation, attribution, hébergement, réutilisation
- Apporter des réponses simples et concrètes
 - Intégrer la gestion des données à la pratique de recherche

Accompagner le processus de recherche – vers un *certificat d'identité des données*

- Vision: agréger à chaque étape tous les éléments pertinents pour la traçabilité d'un jeu de données
 - Acteurs et responsabilités
 - Sources
 - Données techniques, formats
 - Traitements effectués
 - Conditions de diffusion et de réutilisation, licences
- Démarche pragmatique
 - Identifier comment rendre cette gestion naturelle (mais pas transparente) pour la chercheuse ou le chercheur

Tracer la création des jeux de données



Et quand on croit être arrivé au bout...

- Hébergement
 - Données, méta-données
 - Identification, archivage à long terme
 - Autorité?
- Référencement (publications)
 - Citer les jeux de données (et sources) primaires et secondaires
 - Citer les différents acteurs du processus
 - Réutiliser les contenus?

Aborder le système en amont

- De la demande initiale à la réalisation du projet de recherche
- Possible utilisation de SciencesCall
 - Une plate-forme de gestion d'appel à projet
 - Développement à l'UMS CCSD (cf. HAL, Episciences, SciencesConf)
 - Construit suivant un modèle classique de dépôt et évaluation

Pistes pour une utilisation de SciencesCall pour le traçage des données

- Fiche de gestion de données au moment du dépôt
- Intégration d'un point de validation par les acteurs du processus
 - Etablissement patrimonial, équipement, futur hébergeur des données
- Agrégation de métadonnées de la part de ces acteurs

Intégrer tous les acteurs du dispositif

- Le chercheur, la chercheuse
 - Qualifie la recherche et définit le cycle de vie de ses données
- L'établissement patrimonial
 - Détermine les contraintes liées à l'utilisation de ses fonds et les attentes en retour
- L'équipement
 - Détermine une politique d'utilisation de la part des projets de recherche
- L'hébergeur de données
 - Exprime des contraintes sur la taille, les formats, la documentation, les conditions d'accès
- Et bien sûr les politiques européennes, nationales et institutionnelles

Un outil méthodologique

- La charte de réutilisation des données
 - un contrat entre les différents acteurs du processus de recherche
 - fluidifier les échanges et faciliter la réutilisation des données patrimoniales
- Implication d'institutions européennes
 - DARIAH, Europeana, CLARIN, APE, E-RIHS

Les principes fondateurs

Reciprocity

Interoperability

Citability

Trustworthiness

Stewardship

Openness

Tentative d'implémentation

- Partir des rôles et des exigences variés entre acteurs pour faire des recommandations centrées sur les besoins de chacun, mais profitables à tous (approche *bottom-up*)
- Par exemple, pour la « *citability* » :
 - Pour le chercheur ou la chercheuse → citer l'institution d'où viennent les données et l'équipement / l'infrastructure qui est intervenue au cours du projet
 - Pour l'institution patrimoniale → fournir un modèle de citation et communiquer autour des recherches faites à partir de leurs collections
- Tester ces principes à travers **SciencesCall**, plateforme de gestion des appels à projet

Archives départementales des Yvelines

Conditions de réutilisation des documents conservés aux Archives départementales des Yvelines

Vous êtes libre de réutiliser gratuitement et sans formalités les informations contenues dans les documents conservés aux Archives départementales ou les images de ces documents,

Vous pouvez les :

- reproduire, copier, publier et transmettre ;
- diffuser et redistribuer ;
- adapter, modifier, transformer, notamment pour créer des documents dérivés ;
- exploiter à titre commercial.

La réutilisation est gratuite mais la mise à disposition des informations donne lieu à la perception de frais techniques dans les cas où elle entraîne des opérations techniques (reproduction, extraction de données, compression et transfert de fichiers, ...) à la charge du département.

Source: <https://archives.yvelines.fr/article.php?larub=12&titre=reutilisation-des-archives>

Archives Départementales des Yvelines

(Suite)

Sauf s'il s'agit de documents dont vous avez obtenu communication par dérogation, de documents contenant des informations publiques comportant des données à caractère personnel, de documents sur lesquels s'exerce un droit de propriété intellectuelle, ou encore de documents entrés par don ou par dépôt.

...

CAS DES DOCUMENTS COMPRENANT DES DONNÉES À CARACTÈRE PERSONNEL

...

CAS DES DOCUMENTS SUR LESQUELS S'EXERCE UN DROIT DE PROPRIÉTÉ INTELLECTUELLE

...

Et à condition de respecter les conditions suivantes :

- ne pas dénaturer le sens des informations contenues dans les documents ;
- mentionner de manière visible la source des informations et leur lieu de conservation (de préférence sous la forme Archives départementales des Yvelines, précision de la cote) ;
- préciser la date de la production ou de la dernière mise à jour des informations ;
- mentionner le nom de (ou des) auteur(s), s'il y a lieu.

Et pratiquement?

- Priorité au travail avec les chercheurs
 - Doctorants et post-doctorants financés dans le cadre du DIM MAP
 - Séminaire de travail commun le 7 février
 - Echanges personnalisés en mai-juin
- Travailler à une déclaration préalable à intégrer aux demandes de projet sur SciencesCall
 - Intégration des grandes catégories de la charte
- Définir un concept pour intégrer des contraintes multi-acteurs dans ScienceCall
- Vers un guide de gestion des données de recherche à destination des jeunes chercheurs
 - Centré sur les processus de recherche et les types de donnée

Perspectives

- Gestion raisonnée des données
 - Un point de départ pour la transparence scientifique
 - Dans l'espace et le temps
 - Nécessite des compétences et des infrastructures
 - Du temps, de l'argent, des personnels
- Aborder la gestion des données de façon humaine et pragmatique
 - Accompagner le changement en impliquant les chercheurs
 - Permettre une amélioration progressive des conditions de gestion des données de la recherche
 - Mettre en œuvre des solutions pérennes